

부분 모델 공유를 통한 ProxyFL 에너지 효율 개선안 연구

박준영, 이주형
가천대학교

jyp9786@gachon.ac.kr, j17.lee@gachon.ac.kr

A Study on Enhancing Energy Efficiency of ProxyFL via Partial Model Sharing

Jun Young Park, Joohyung Lee
Department of Computing, Gachon University

요 약

기존 탈중앙 연합학습 방법인 Proxy Federated Learning (ProxyFL)은 통신 및 계산 오버헤드 문제와 함께, 프록시 모델의 성능 저하로 인한 지식 전달 품질 문제가 발생한다. 이에 본 연구는 프록시 모델의 분류기 부분만을 학습 및 공유하고 개인 모델의 특징 추출기를 해당 분류기 학습에 활용함으로써 에너지 효율과 지식 전달의 질을 동시에 개선하는 E-ProxyFL 프레임워크를 제안한다.

I. 서 론

연합학습 (Federated Learning, FL)은 분산된 클라이언트들이 개인 데이터를 로컬에 저장한 채, 중앙 서버와 원시 데이터를 공유하지 않고 공동으로 모델을 학습하는 방식이다 [1]. 하지만 중앙 서버에 의존하는 학습 구조는 단일장애점 문제와 서버 측의 통신 병목 현상과 같은 본질적인 한계를 갖는다. 이러한 중앙 집중형 구조의 단점을 극복하기 위해, 중앙 서버의 개입 없이 클라이언트 간에 모델 파라미터를 Peer-to-Peer (P2P) 방식으로 직접 교환하며 학습을 진행하는 탈중앙 연합학습 방법론들이 제안되었다.

Proxy Federated Learning (ProxyFL) [2]은 대표적인 탈중앙 연합학습 방법론으로, 각 클라이언트는 추론 성능을 위한 개인 모델과 다른 클라이언트와 공유하는 경량 프록시 모델을 유지 및 학습한다. 학습 과정에서 두 모델은 Deep Mutual Learning (DML)을 통해 서로의 지식을 상호 전달하며 학습하고, 프록시 모델만을 P2P 방식으로 타 클라이언트와 공유한다.

ProxyFL은 경량화된 모델만을 공유함으로써 통신 효율을 일부 개선하였으나, 매 라운드마다 프록시 모델을 업데이트하고 전송하는 과정에서 여전히 상당한 계산 및 통신 오버헤드를 유발한다. 따라서 프레임워크의 에너지 효율성을 더욱 높이기 위해 공유 모델의 크기를 감소시킬 수 있는 추가적인 개선 방안이 필요하다.

이에 본 연구에서는 각 클라이언트가 프록시 모델의 일부분만을 유지함으로써 에너지 효율성을 향상시키는 E-ProxyFL 을 제안한다. 각 클라이언트는 프록시 모델 전체가 아닌 분류기 (Classifier) 파트만 학습하고 공유하며 계산 및 통신 오버헤드를 줄일 수 있다. 해당 프레임워크를 통해 부분 모델 학습 및 공유의 효용성에 대해 실험적으로 분석하였고, 그 결과 제안된 E-ProxyFL 은 기존 ProxyFL 대비 CIFAR-10 데이터셋에 대해 평균 9.7%의 정확도 향상, 약 50.4%의 통신 에너지

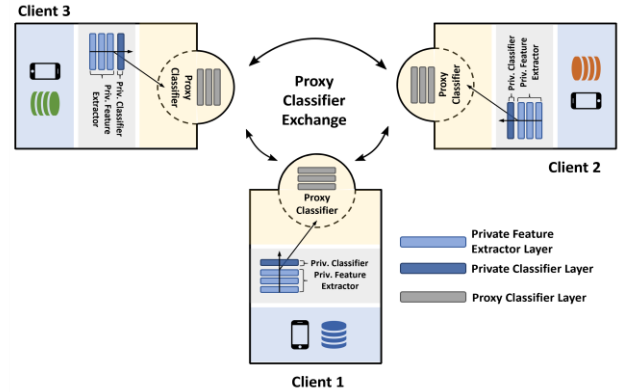


그림 1. E-ProxyFL 프레임워크의 개요도

효율 개선 및 약 17.2%의 계산 에너지 효율 개선이 있음을 보여준다.

II. 본론

가. ProxyFL

ProxyFL의 클라이언트는 개인 모델과 프록시 모델을 학습한다. 이 중 프록시 모델은 타 클라이언트와 공유되어 외부 지식을 수집하고, 이 지식을 DML을 통해 개인 모델에 전달하여 개인 모델의 일반화 성능을 높이는 데 기여한다. 이때, 프록시 모델은 개인 모델과 달리 외부로 공유되기에 통신 효율을 위해 경량화된 모델을 사용하며, 모델 파라미터 공유로 인한 정보 유출 위험을 줄이기 위해 Differential Privacy (DP)를 적용하여 업데이트한다. 그렇기에 프록시 모델은 개인 모델에 비해 저하된 성능을 가지며, 성능이 저하된 프록시 모델의 지식을 전달받아 개인 모델을 학습하는 것은 개인 모델의 성능을 저하시키는 원인이 될 수 있다.

나. E-ProxyFL

제안된 E-ProxyFL은 성능이 저하된 프록시 모델로부터 지식을 전달받음으로써 발생하는 부정적 영향을 완화하고, ProxyFL의 에너지 효율을 개선하고자 한다. 이에 프록시 모델을 전부 유지하는 것이 아닌, Classifier 부분만을 보유하며 이를 프록시 Classifier라 한다. 그림 1에서와 같이, 제안된 E-ProxyFL에서 프록시 Classifier의 예측은 개인 모델의 특징 추출기(Feature Extractor)를 이용해 추출한 특징을 입력으로 사용해 이루어지고, 개인 모델의 예측은 프록시 Classifier보다 가벼운 개인 모델 Classifier를 통해 수행된다.

이러한 방식을 통해 제안된 E-ProxyFL은 다음과 같은 두 가지 주요 이점을 얻을 수 있다. 첫째, 성능이 우수한 개인 모델의 Feature Extractor를 활용함으로써 프록시 Classifier는 고품질의 특징을 기반으로 학습할 수 있다. 이는 기존 ProxyFL에서 경량화 및 DP로 인해 성능이 저하될 수밖에 없는 프록시 모델 자체의 Feature Extractor에 의존하는 경우보다 프록시 Classifier의 학습 품질을 향상시킨다. 이렇게 향상된 프록시 Classifier의 예측 정확도는 DML 과정을 통해 개인 모델에게 보다 유용한 지식을 전달하게 되며, 궁극적으로 개인 모델의 일반화 성능 개선에 기여한다.

둘째, 클라이언트는 프록시 모델 전체가 아닌 프록시 Classifier만을 학습하고 공유함으로써 연산 및 통신 과정에서의 에너지 소모를 절감할 수 있다. 또한, 모델의 크기가 작아져 클라이언트의 메모리 사용량 또한 효과적으로 줄일 수 있는 이점이 있다.

이때, 프록시 Classifier의 크기를 줄일수록 에너지 소모량을 더욱 절감할 수 있다. 하지만 이는 프록시 Classifier를 통한 추론 성능을 저하시킬 수 있으며, DML을 통해 개인 모델로 전달되는 지식의 질 또한 하락하게 될 수 있다. 이러한 지식 품질의 저하는 개인 모델의 핵심 목표인 일반화 성능 하락으로 이어질 수 있으며, 에너지 효율성 증대와 모델 정확도 간의 trade-off를 형성한다. 따라서 에너지 효율성과 모델 성능 간의 균형을 고려하여 접근해야 한다.

다. 실험결과

제안된 E-ProxyFL과 기존 ProxyFL의 성능을 CIFAR-10 데이터셋을 통해 검증하였으며, p_{major} 는 클라이언트가 보유한 데이터의 클래스 불균형 정도를 나타낸다. 예를 들어, $p_{major} = 0.5$ 이면 특정 클래스의 데이터가 50%를 차지한다. 높을수록 특정 클래스를 많이 보유해 불균형 정도가 심해지며, p_{major} 값을 0.3, 0.4, 0.5, 0.6, 0.7로 설정하여 각 수치에서 성능을 비교하였다. 각 p_{major} 값 별로 5번 실험을 진행하여 얻은 평균값을 그림 2와 표 1에 표기하였다.

그림 2는 $p_{major} = 0.5$ 의 클래스 불균형 조건에서, 제안된 E-ProxyFL의 개인 모델과 프록시 Classifier를 이용한 추론이 기존 ProxyFL 모델들보다 높은 정확도를 달성함을 보여준다. 이는 제안된 E-ProxyFL의 프록시 Classifier가 개인 모델의 우수한 Feature Extractor를 기반으로 학습한 결과로 해석할 수 있다. 이로 인해 기존 ProxyFL의 성능이 저하된 전체 프록시 모델이 DML을 통해 제공하는 지식보다 더욱 유용한 중간 지식을 제공할 수 있고, 이는 개인 모델과 프록시 Classifier를 통한 추론 성능 향상 모두에 기여한다.

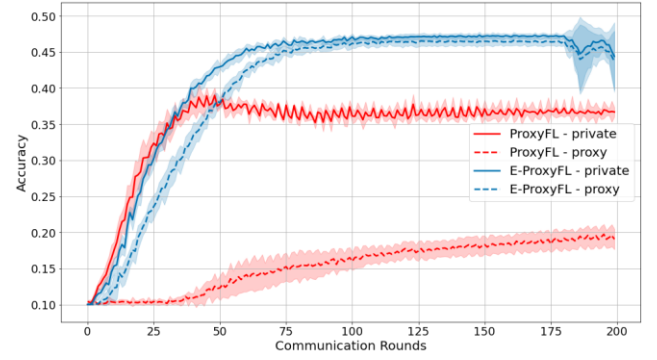


그림 2. $p_{major} = 0.5$ 일 때의 정확도 그래프

p_{major}	0.3	0.4	0.5	0.6	0.7	통신 에너지 소모량	계산 에너지 소모량
ProxyFL - proxy	26.45%	22.28%	19.05%	15.7%	13.56%	100%	100%
ProxyFL - private	41.01%	39.94%	36.68%	32.26%	28.23%		
E-ProxyFL - proxy	48.49%	47.24%	43.69%	42.37%	39.85%	49.6%	82.8%
E-ProxyFL - private	49.27%	48.72%	44.39%	43.53%	40.71%		

표 1. p_{major} 별 정확도 및 에너지 소모량 비교 결과표

이러한 양상은 표 1에서도 나타나며, 제안된 E-ProxyFL의 두 가지 모델을 이용한 추론이 모든 p_{major} 값에서 기존 ProxyFL의 방법보다 높게 나타나는 것을 확인할 수 있다. 이는 제안된 E-ProxyFL이 데이터 불균형 상황에서도 더욱 견고함을 입증한다.

또한, 본 실험에 사용된 모델 아키텍처에서 프록시 Classifier는 전체 프록시 모델 파라미터 수의 약 49.6%만을 차지한다. 이는 클라이언트 간 통신 데이터 양을 약 50.4% 감소시켜 통신 효율성을 향상시키는 결과로 이어진다. 또한, 제안된 E-ProxyFL의 클라이언트는 개인 모델과 더불어 프록시 Classifier만을 추가로 학습 및 업데이트하므로, 본 실험 구성 기준으로 클라이언트의 전체 연산량 역시 기존 ProxyFL 대비 약 17.1% 감소시키는 계산 효율성 개선을 보여준다.

III. 결론

본 연구는 ProxyFL의 에너지 효율성 개선을 위해 프록시 모델의 Classifier 부분만을 유지하여 학습 및 공유하는 E-ProxyFL을 제안하였다. 실험 결과 제안된 프레임워크는 다양한 데이터 분포 상황에서도 견고함을 보여주었고, 에너지 효율성 역시 유연하게 개선시킬 수 있음을 확인하였다. 이는 E-ProxyFL의 효율성을 입증하며, 추후 Classifier 크기, 모델 공유 빈도 최적화 등을 통한 성능 및 효율성 개선이 기대된다.

ACKNOWLEDGMENT

본 연구는 한국과학기술정보연구원(KISTI)의 위탁연구개발 과제로 수행한 것입니다. (과제번호 K25L5M2C2/P25030)

참고 문헌

- [1] H. B. McMahan, E. Moore, D. Ramage, S. Hampson, and B. A. y. Arcas, "Communication-efficient learning of deep networks from decentralized data", arXiv preprint arXiv:1602.05629, 2016.
- [2] Kalra, S., Wen, J., Cresswell, J.C. *et al*, "Decentralized federated learning through proxy model sharing", *Nat Commun* 14, 2899, 2023.